



O Potencial Uso de Dados Geoespaciais do Consumo de Energia Elétrica como Vetor de Previsão da Demanda Residencial¹

Nivalde de Castro²

Francesco Tommaso³

O acelerado desenvolvimento do *Big Data* ocorrido ao longo das últimas duas décadas, decorrente do aumento da capacidade de processamento e armazenamento dos computadores e da maior amplitude e variedade na geração e medição de dados. Esta nova dimensão do conhecimento tem impactado os mais diversos setores da economia, provendo e abrindo oportunidades para novos negócios, produtos e serviços, ou mesmo na otimização de procedimentos operacionais e estratégicos (LEE, 2017).

O Setor Elétrico apresenta perspectivas promissoras para a aplicação de técnicas analíticas que façam uso do *Big Data*. Avanços tecnológicos, aliados à necessidade de flexibilização e adaptação das redes de distribuição, têm conduzido, por exemplo, ao gradual desenvolvimento de redes inteligentes capazes de coletar dados com maior atômica e discretização temporal. Esta obtenção de dados em grande quantidade permite que sejam elaborados modelos com a finalidade de se compreender as inúmeras relações entre os consumidores e a rede, o que pode derivar no eventual uso

¹ Artigo publicado pela Agência Canal Energia. Disponível em: <https://www.canalenergia.com.br/artigos/53062822/o-potencial-uso-de-dados-geoespaciais-do-consumo-de-energia-eletrica-como-vetor-de-previsao-da-demanda-residencial>. Acesso em: 30 de maio de 2018

² Professor do Instituto de Economia da UFRJ e coordenador do GESEL- Grupo de Estudos do Setor Elétrico.

³ Pesquisador líder do GESEL-UFRJ

desses resultados para a otimização de processos operacionais, estrutura tarifária e outros fins inovadores (DEIGN, 2017).

Uma possível aplicação do *Big Data* ao Setor Elétrico seria o uso de dados geoespaciais associados a instrumentos de medição das redes físicas de distribuição, com o intuito de determinar modelos geoespaciais para consumidores e instalações físicas. Estes modelos têm potencial para amparar a gestão das redes de distribuição, provendo auxílio às decisões de investimento, operação e manutenção.

Um exemplo nesta direção é o estudo desenvolvido por Damilola (2013), onde foram empregados dados geoespaciais, como mapas urbanos e dados de GPS, captados a partir de um trabalho de campo que visava a localização dos equipamentos elétricos. Utilizaram-se, também, dados não espaciais, como detalhes dos consumidores e dados técnicos das redes de distribuição, providos pela Power Holding Company Nigeria⁴.

O objetivo do estudo foi identificar o efeito da provisão de dados, em tempo real, das condições da rede de distribuição sobre a gestão das mesmas. O estudo indicou que será possível, dentre outras possibilidades:

- i. Auxiliar a identificar, rapidamente, os locais onde era maior a necessidade de reposição de equipamentos, de acordo com a qualidade da energia em determinada localidade, e
- ii. Prover dados locais para auxiliar na operação e reparo da rede, em casos de interrupções do fornecimento.

O estudo chegou às conclusões de que:

- i. Grande parte da estrutura da rede estava em más condições, exigindo a sua substituição (ou melhoria da manutenção), e
- ii. Havia grande desequilíbrio locacional da carga dentro da região estudada, não observável sob condições normais de monitoramento.

Uma das maiores dificuldades para a aplicação dos modelos geoespaciais é a necessidade da instalação de equipamentos de medição ao longo da rede, tornando o investimento elevado e antieconômico (DAMIOLA, 2013). Os equipamentos de medição são necessários, visto que as informações dos consumidores são genéricas e relacionadas ao seu comportamento médio, obtidas por meio de entrevistas de campo e modelos estatísticos. Além disso, tais dados não possuem um perfil locacional.

⁴ Antiga autoridade nacional que governava o uso da energia elétrica na Nigéria.

Ao longo da última década, o explosivo crescimento do uso cada vez mais cotidiano de *smartphones*, com a sua grande e crescente interconectividade, tem impactado a indústria de serviços geoespaciais. Atualmente, mais de dois terços da população mundial utiliza *smartphones* e seu uso tem possibilitado a obtenção de muitos tipos de dados, incluindo os locais. Uma grande vantagem da obtenção destes dados é que, em função de economias de escopo, eles são adquiridos a baixos custos. A função de GPS, presente nos dispositivos, permite que os dados locais sejam obtidos sem investimentos físicos adicionais. Serviços, como o Uber, utilizam este tipo de dados intensivamente e a baixo custo (OPDYCKE, 2017).

Caberia, então, a seguinte pergunta: esses dados não poderiam ser utilizados como dados de entrada para a construção de modelos geoespaciais das redes de distribuição, com o objetivo de compreender e interpretar a localização e os picos de demanda da baixa tensão? Um exemplo de utilização dos modelos geoespaciais seria para a compreensão da formação periódica de locais de elevada concentração populacional (*hotspots*). Neste caso, seria possível substituir parte dos investimentos físicos, como os indicados pelo estudo de Damilola (2013).

Outro exemplo de aplicação seria no mapeamento dos riscos da demanda de pico dos consumidores residenciais, considerando que, atualmente, não há grandes estudos sobre este tema na Europa.

“Whilst a vast amount of data is available with regard to the risks associated with generation, transmission, distribution and supply of electricity, no research has endeavored to model the risk of aggregate peak electricity demand at the European level. Residential electricity demand profiles are highly correlated with the timing of appliance use”.
(TORRITI, 2017)

Um grande desafio no uso destes modelos é que há certa limitação dos dados sobre os consumidores. Os dados utilizados para calcular o risco de picos de demanda acima da demanda esperada⁵ são oriundos de pesquisas nacionais, a partir de respostas de questionários desenvolvidos para estimar os padrões dos consumidores de uso de eletrodomésticos e de permanência nas residências.

A partir dos padrões verificados, são gerados dados de “tempo de uso”, com modelagem estatística e probabilísticas e uso de cadeias de Markov. Estes modelos probabilísticos tentam inferir a probabilidade de ocupantes entrarem ou deixarem uma determinada residência em intervalos de 10 minutos (TORRITI, 2017). Aqui,

⁵ O modelo é focado na frequência com que o uso de bens de consumo elétricos excedem um certo valor “w”, que corresponde ao nível fixo de oferta que as redes europeias podem tolerar (TORRITI, 2017).

novamente, nota-se o potencial de utilização dos dados geoespaciais providos pelos *smartphones*, cuja aplicação permitiria uma maior precisão do modelo.

Certamente, há espaço para outras aplicações de dados geoespaciais ao Setor Elétrico. Se seu custo de aquisição for menor do que o custo de meios alternativos, sua aplicação poderia substituir outros dados na geração de modelos importantes para a otimização das redes do Setor Elétrico.

REFERÊNCIAS:

DAMILOLA, Dare-alao. *Geospatial Modeling of Electricity Distribution Network*. 2013. Disponível em: <<https://www.geospatialworld.net/article/geospatial-modeling-of-electricity-distribution-network/>>. Acesso em: 01 mar. 2018.

DEIGN, Jason. *Big Data and Artificial Intelligence Deals in the Energy Sector Are Up Tenfold in 2017*. 2017. Disponível em: <<https://www.greentechmedia.com/articles/read/big-data-and-ai-deals-in-energy-are-up-10-fold-in-2017>>. Acesso em: 01 mar. 2018.

LEE, In. Big data: Dimensions, evolution, impacts, and challenges. *Business Horizons*. Illinois, p. 1363-1374. mar. 2017.

OPDYCKE, John. *How Utilities Are Deploying Data Analytics Now*. 2017. Disponível em: <<http://www.bain.com/publications/articles/how-utilities-are-deploying-data-analytics-now.aspx>>. Acesso em: 01 mar. 2018.

TORRITI, Jacopo. *The Risk of Residential Peak Electricity Demand: A Comparison of Five European Countries*. *Energies*. Whiteknights, p. 385-399. mar. 2017.